Data Science Studio初步使用报告

1. Data Science Studio（DSS）

Data Science Studio是Data iku公司研发的一款数据分析软件。Data Science Studio整合了从数据整合，数据清洗，可视化分析，机器学习以及到最后的产品发布的整一个流程。它把数据库，可视化分析，机器学习等大数据中使用到的工具都模块化了，提供了一个统一的操作界面。

2. Flow

在Data Science Studio中，所有的操作步骤都可以被记录下来，作为一套固定的流水线，类似于写程序。对于新数据，我们就可以快速使用原有的流水线进行处理。首先我们需要介绍一些概念：Dataset，Recipe，Machine Learning。

2.1. Dataset

使用Data Science Studio的第一步就是提供数据，Data Science Studio支持一系列数据库连接和离线文件，数据库包括MySQL，PostgreSQL，Oracle，Microsoft SQL Server，MongoDB和Twitter (Streaming API)等，离线文件包括基于文件系统, HDFS, Amazon S3, HTTP, FTP, SSH等协议下的文件，文件格式包括CSV，EXCEL，JSON，MySQL Dump和Apache Combined log format。一个dataset的图标是一个蓝色的方块，其中的图标表明的他的来源。左边所示的是一个来自上传文件的数据集，右边是一个上传按钮，显示了可以连接的各种数据源及图标。

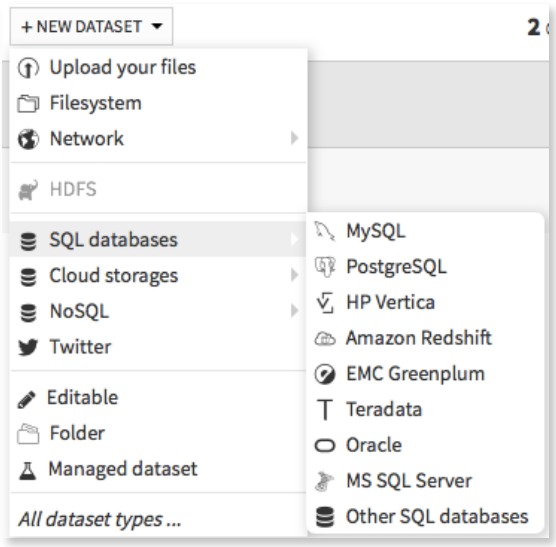

2.2. Recipe

Recipe是对数据的一次处理，每对数据做一次transformation，aggregation，join等都会产生一个recipe。所以一个数据集经过一个recipe就生成一个新的数据集，可以说前者是recipe的输入，后者是recipe的输出。一个recipe由Data Science Studio中的工具可视化实现（比如一些数据清洗），或者是一些编程语句（）。下图所示的就是在从一个数据集经过Data Science Studio的工具得到的新数据集的过程，其中recipe展示为黄色的圆形（通过Data Science Studio实现的处理），不同的图案代表不同的含义。如果是通过编程语句实现的，就会显示为红色圆形，图案是相应的编程语言（由于没有连接相应的数据库，截图中的图案都是灰色的）。

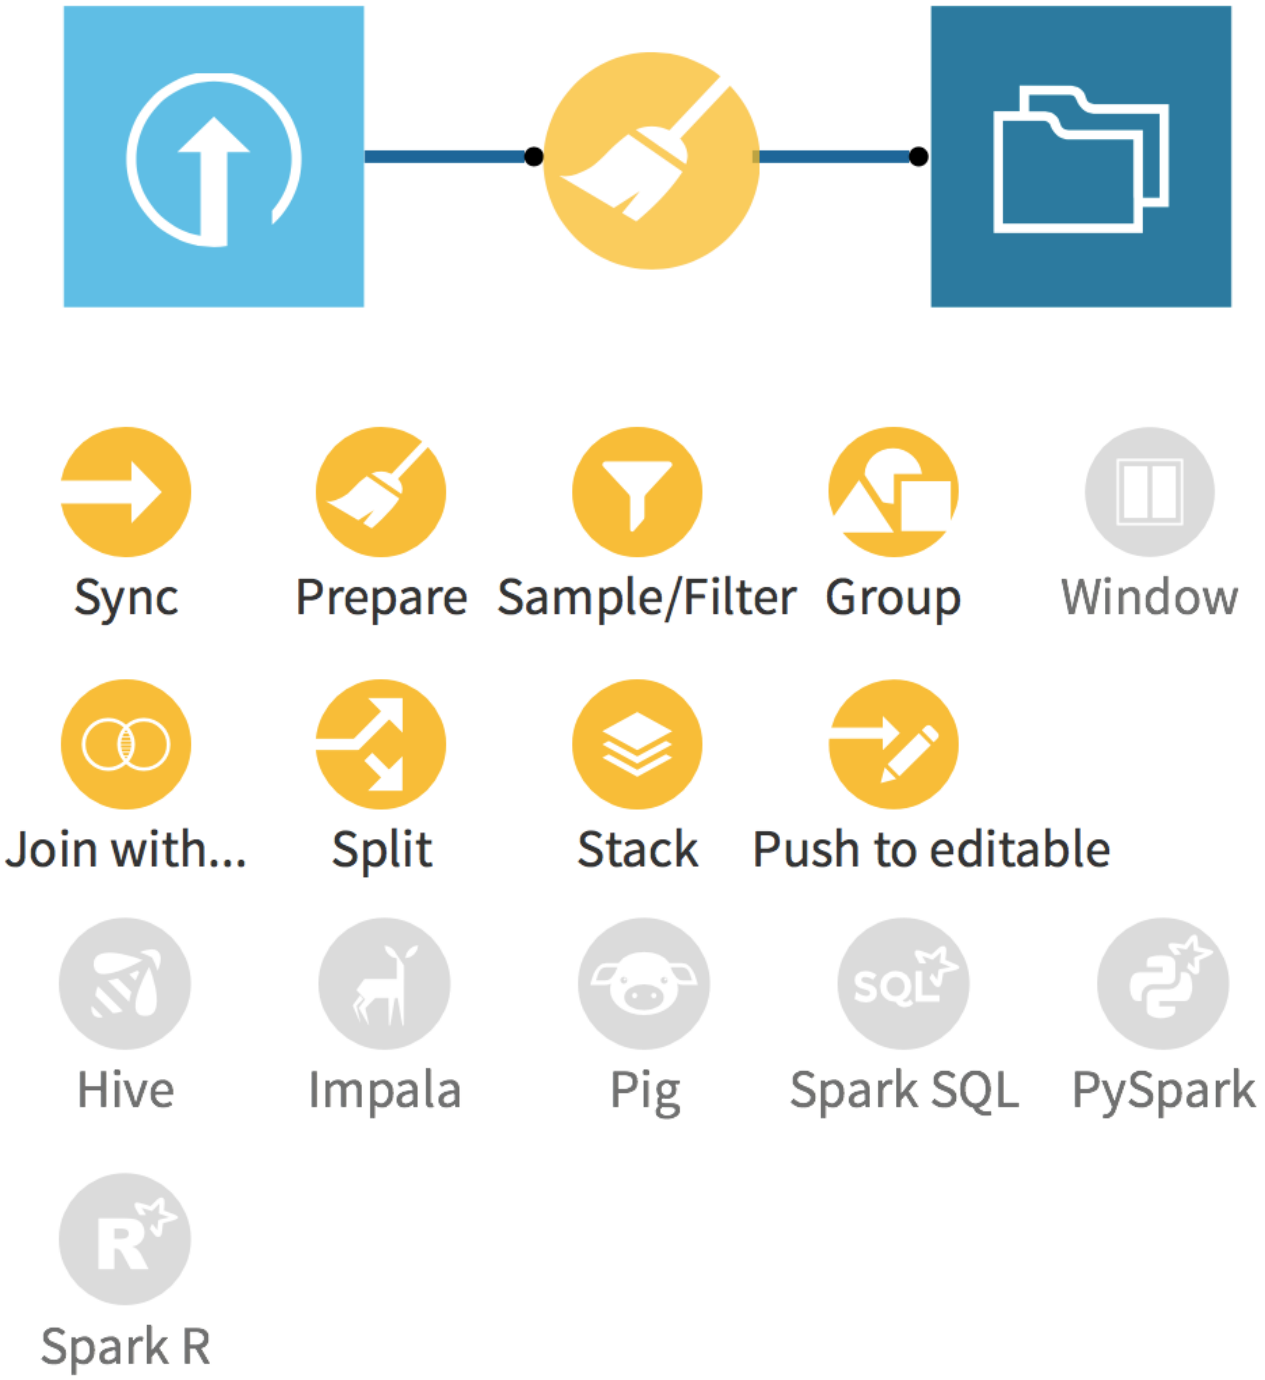

2.3. Machine Learning

Data Science Studio系统中也集成了一些机器学习的工具，可以直接用来预测某些值。我们可以不断调节参数来提高模型的指标。下面是两个模型的截图。机器学习的过程使用绿色显示，杠铃代表模型训练事件，散点图代表模型计分，奖杯代表把模型应用到新的数据库中。

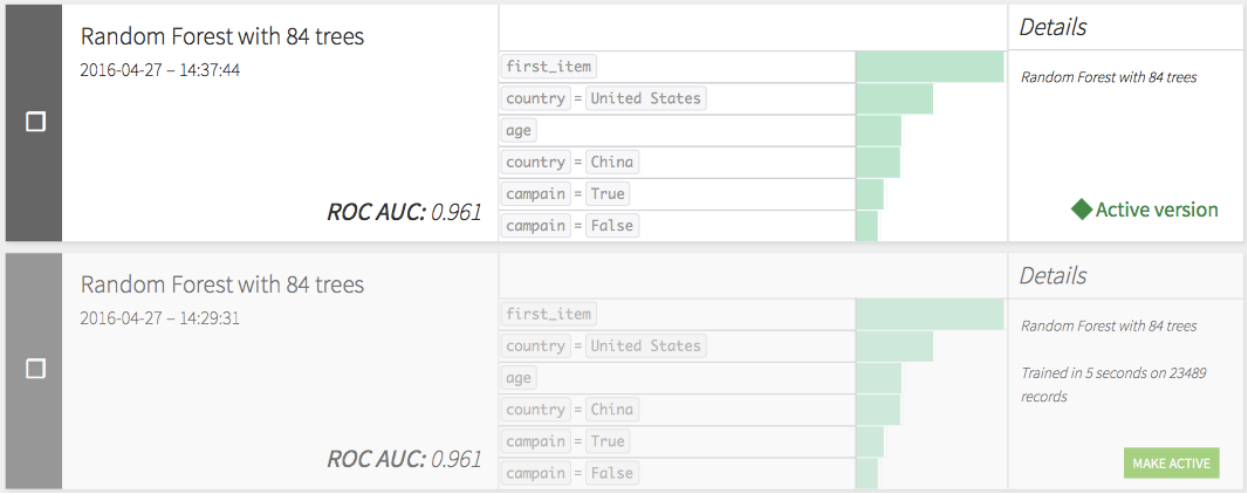

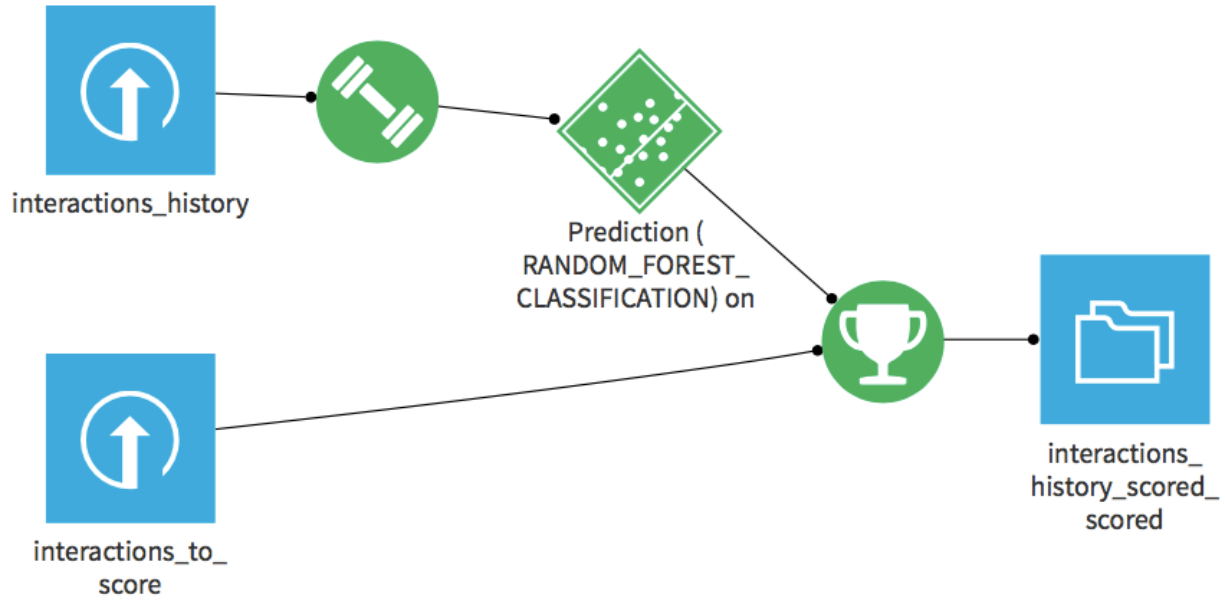

2.4 Flow

Dataset，Recipe和Machine Learning构成了整一个Flow（在网站中只说到了Dataset和Recipe），这构成了我们数据处理的整一个流程，通过Flow，我们可以快速了解数据流水线式如何构成的。下面两张图是一些Flow的例子。


unlabeled_
customers
unlabeled_
customers_
prepared
unlabeled_
customers_within_
segments
customers
customers_
prepared
Segments model
(KMEANS)
customers_within_
segments
Churn prediction
model (RANDOM_
FOREST)
unlabeled_
customers_churn_
prediction
revenue_loss

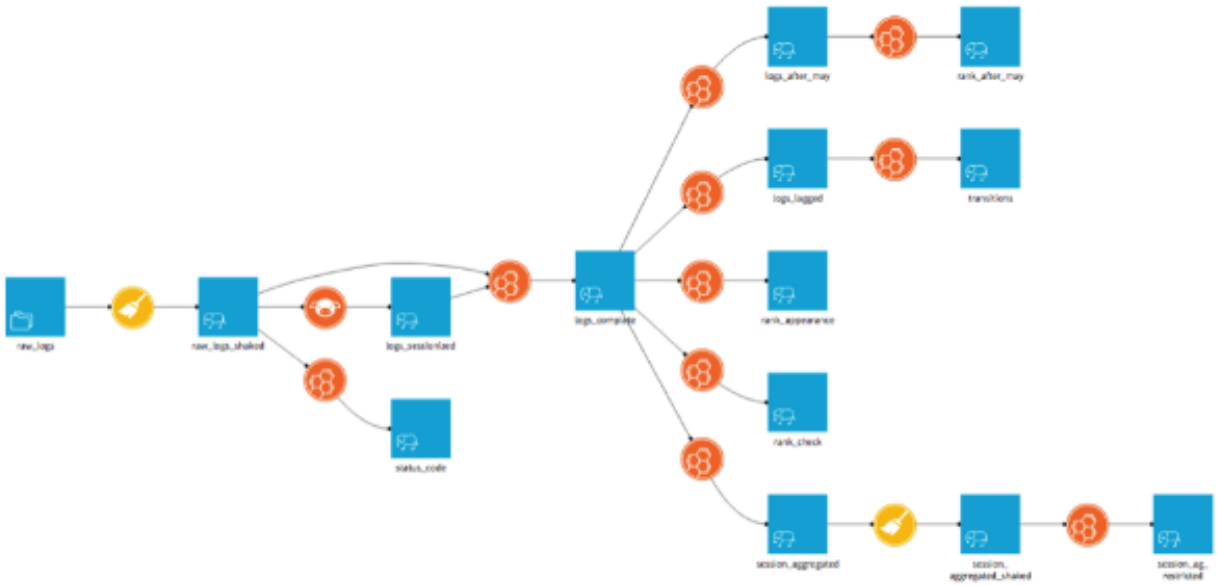
raw_logs
raw_logs_shaked
logs_sessionized
status_code
logs_complete
logs_after_may
rank_after_may
logs_tagged
transitions
rank_appearance
rank_check
session_aggregated
session_
aggregated_shaked
session_ag_
restricted

3. 其他一些功能

其他一些功能包括数据清洗，图标制作，内容发布。

3.1 数据清洗

在2.2 Recipe中提到的，我们可以通过Data Science Studio完成一些数据清洗。下面简单介绍一下。

3.1.1导入数据

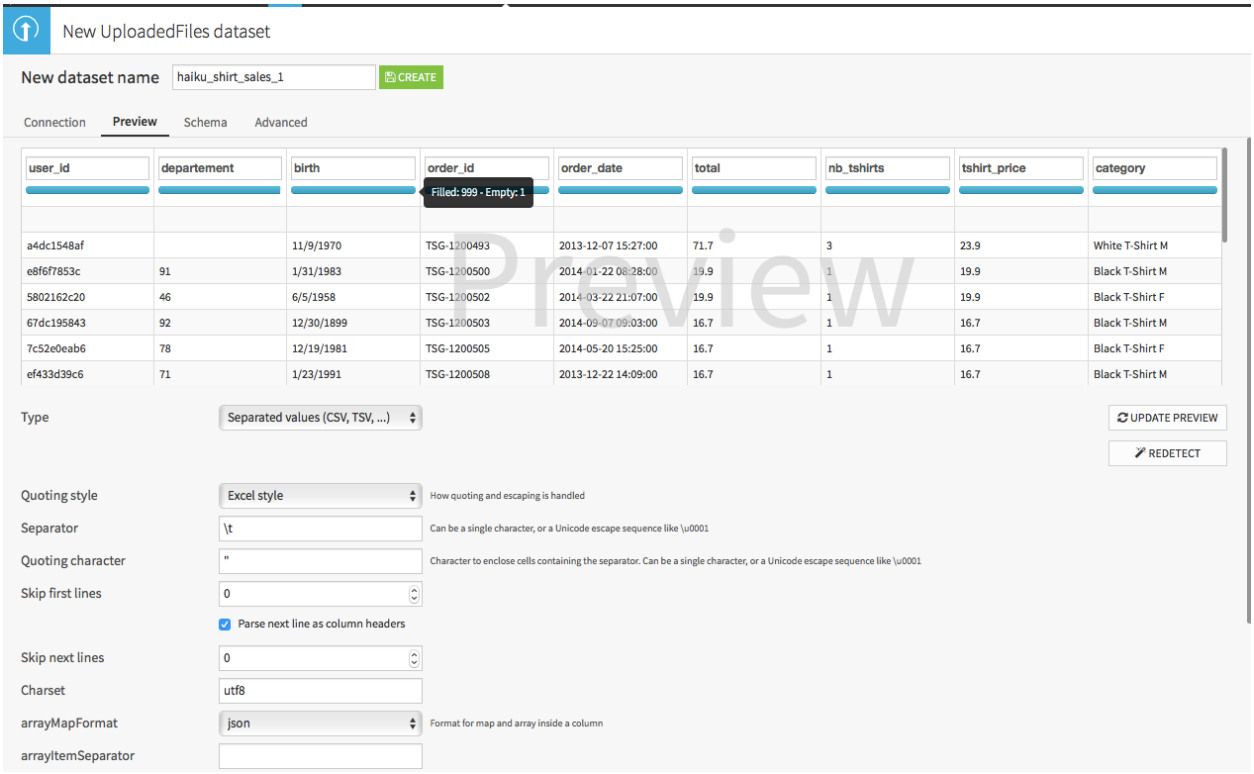

3.1.2导入数据后，我们可以看到一个对字段完整性的统计。
我们看到department字段下面的状态条不全是绿的，有一部分是红色（不符合字段类型int），有一部分是白色的（没有数据）。我们可以通过Data Science Studio系统完成对确实字段的数据删除，和对字段类型预测的修改（修改int为text）。

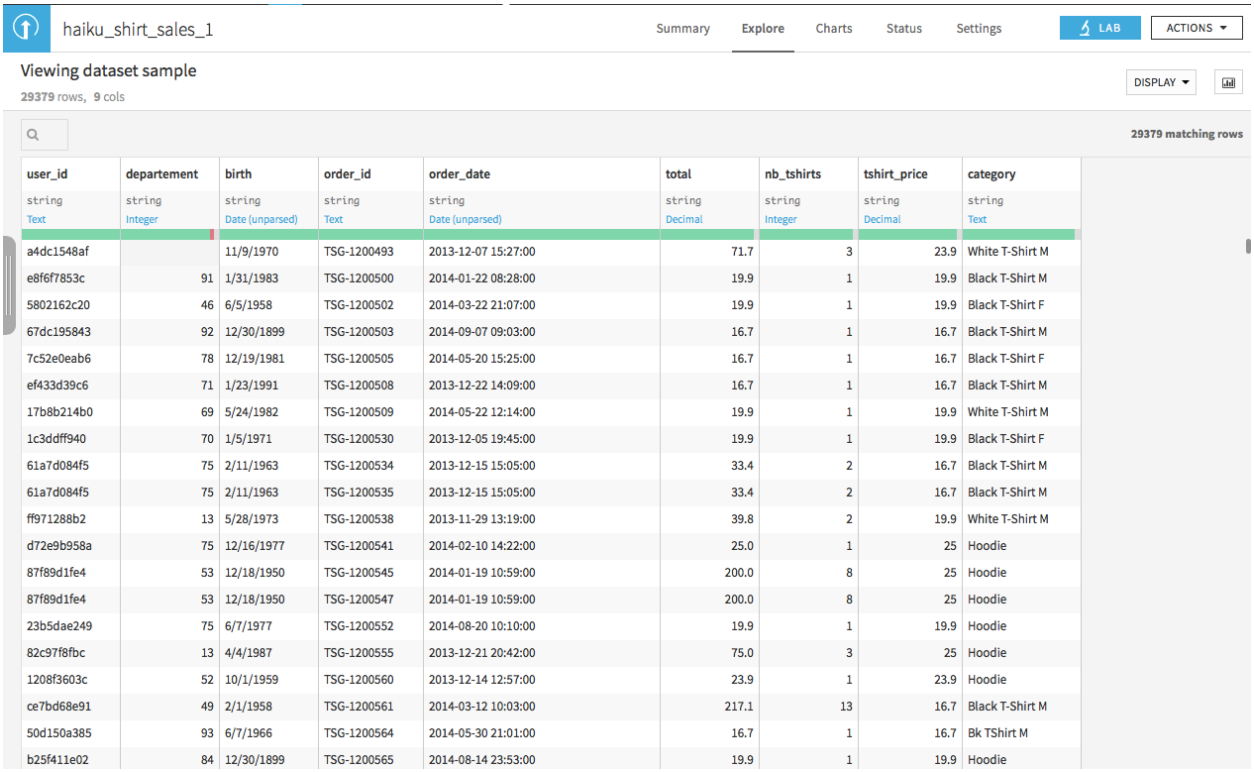

user_id	departement	birth	order_id	order_date	total	nb_tshirts	tshirt_price	category
string Text	string Integer	string Date (unparsed)	string Text	string Date (unparsed)	string Decimal	string Integer	string Decimal	string Text
a4dc1548af		11/9/1970	TSG-1200493	2013-12-07 15:27:00	71.7	3	23.9	White T-Shirt M
e8f6f7853c	91	1/31/1983	TSG-1200500	2014-01-22 08:28:00	19.9	1	19.9	Black T-Shirt M
5802162c20	46	6/5/1958	TSG-1200502	2014-03-22 21:07:00	19.9	1	19.9	Black T-Shirt F
67dc195843	92	12/30/1899	TSG-1200503	2014-09-07 09:03:00	16.7	1	16.7	Black T-Shirt M
7c52e0eab6	78	12/19/1981	TSG-1200505	2014-05-20 15:25:00	16.7	1	16.7	Black T-Shirt F
ef433d39c6	71	1/23/1991	TSG-1200508	2013-12-22 14:09:00	16.7	1	16.7	Black T-Shirt M
17b8b214b0	69	5/24/1982	TSG-1200509	2014-05-22 12:14:00	19.9	1	19.9	White T-Shirt M
1c3ddff940	70	1/5/1971	TSG-1200530	2013-12-05 19:45:00	19.9	1	19.9	Black T-Shirt F
61a7d084f5	75	2/11/1963	TSG-1200534	2013-12-15 15:05:00	33.4	2	16.7	Black T-Shirt M
61a7d084f5	75	2/11/1963	TSG-1200535	2013-12-15 15:05:00	33.4	2	16.7	Black T-Shirt M
ff971288b2	13	5/28/1973	TSG-1200538	2013-11-29 13:19:00	39.8	2	19.9	White T-Shirt M
d72e9b958a	75	12/16/1977	TSG-1200541	2014-02-10 14:22:00	25.0	1	25	Hoodie
87f89d1fe4	53	12/18/1950	TSG-1200545	2014-01-19 10:59:00	200.0	8	25	Hoodie
87f89d1fe4	53	12/18/1950	TSG-1200547	2014-01-19 10:59:00	200.0	8	25	Hoodie
23b5dae249	75	6/7/1977	TSG-1200552	2014-08-20 10:10:00	19.9	1	19.9	Hoodie
82c97f8fbc	13	4/4/1987	TSG-1200555	2013-12-21 20:42:00	75.0	3	25	Hoodie
1208f3603c	52	10/1/1959	TSG-1200560	2013-12-14 12:57:00	23.9	1	23.9	Hoodie
ce7bd68e91	49	2/1/1958	TSG-1200561	2014-03-12 10:03:00	217.1	13	16.7	Black T-Shirt M
50d150a385	93	6/7/1966	TSG-1200564	2014-05-30 21:01:00	16.7	1	16.7	Bk TShirt M
b25f411e02	84	12/30/1899	TSG-1200565	2014-08-14 23:53:00	19.9	1	19.9	Hoodie

3.1.3 字段值分布

我们可以容易地看到各个字段的值得分布

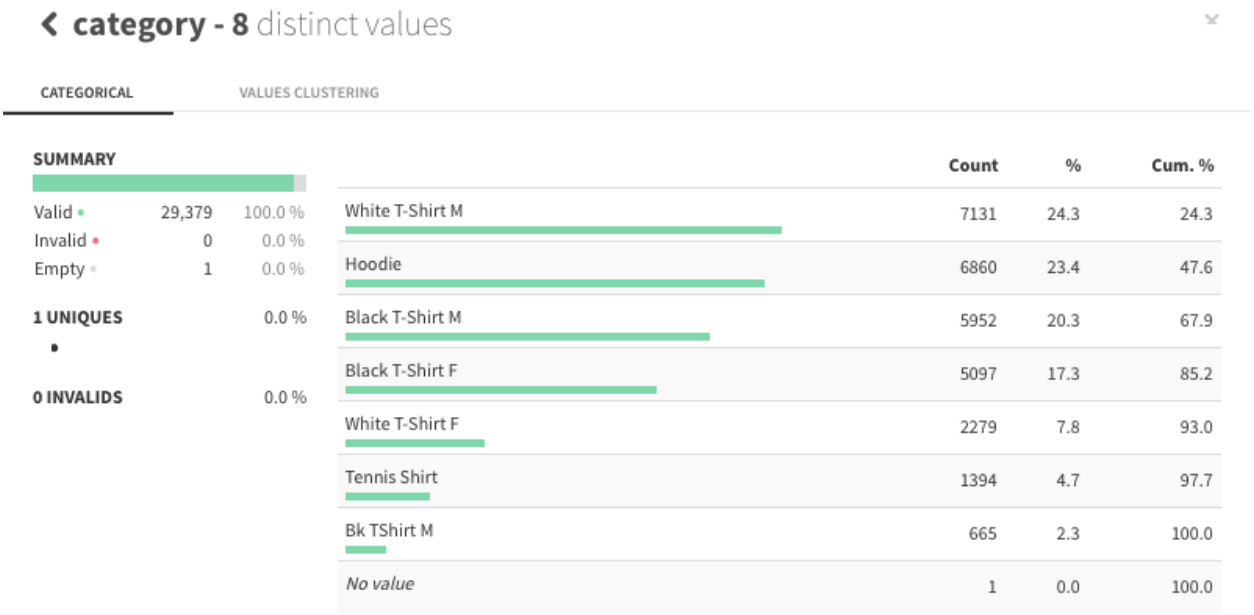

3.1.4 合并相似值

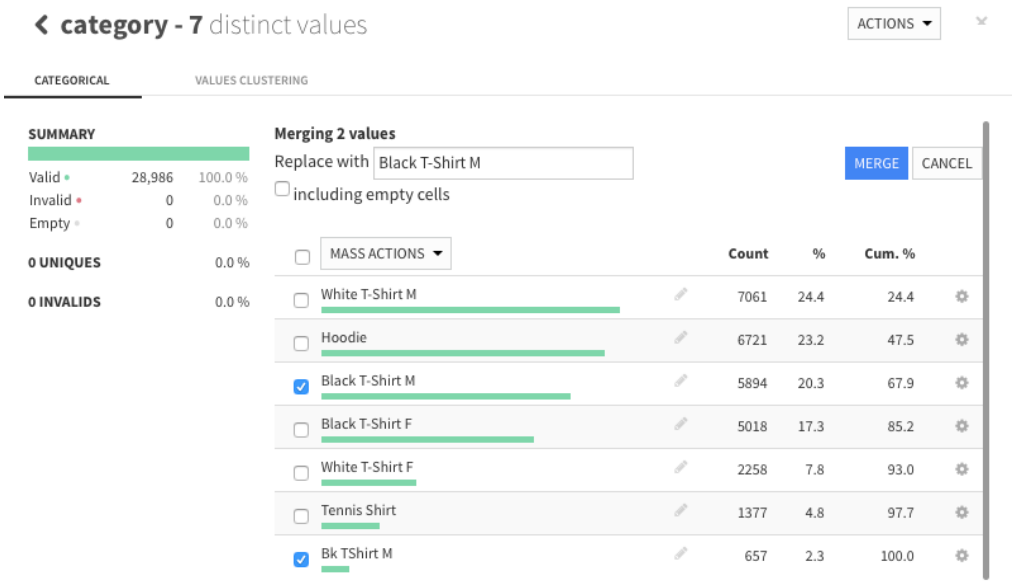

3.1.5 历史记录

对数据集做的改变都会记录下来，可以随意查看或者修改。

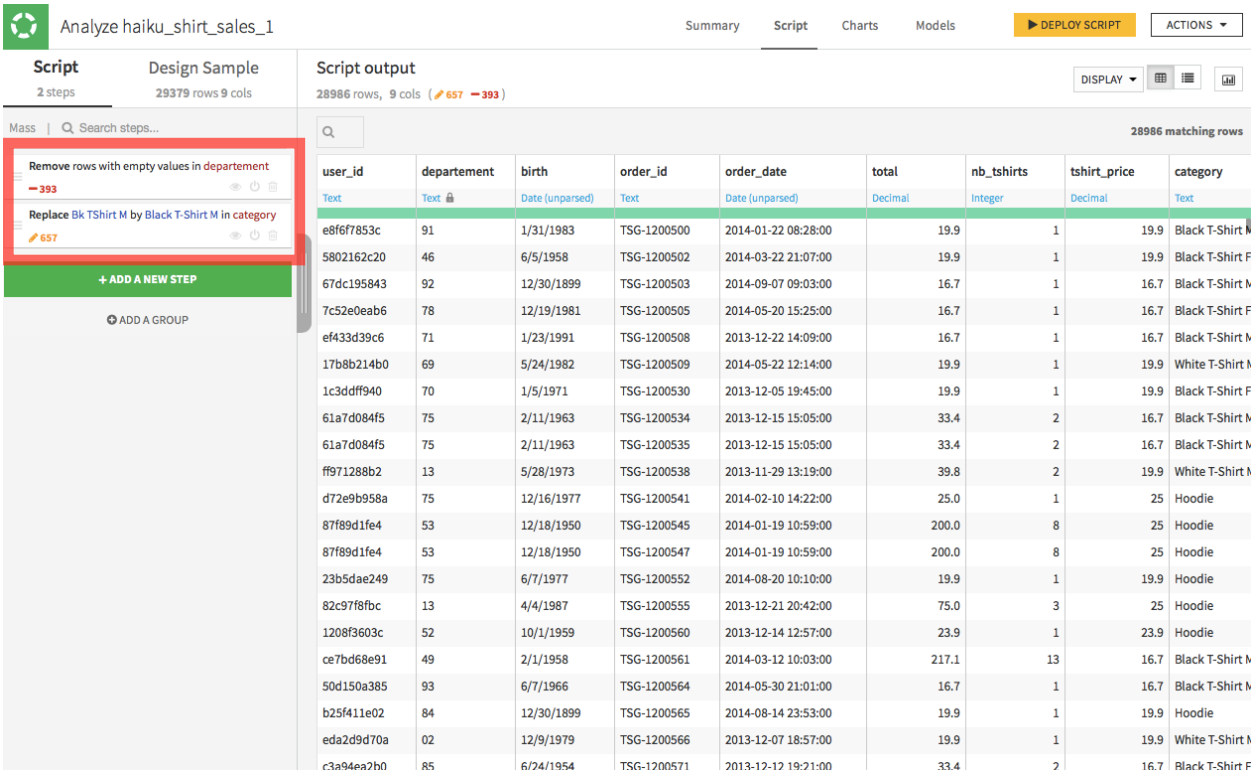

3.2 可视化

可视化展示只提供了一些常用的使用，类似于excel，使用起来还是比较顺手的。

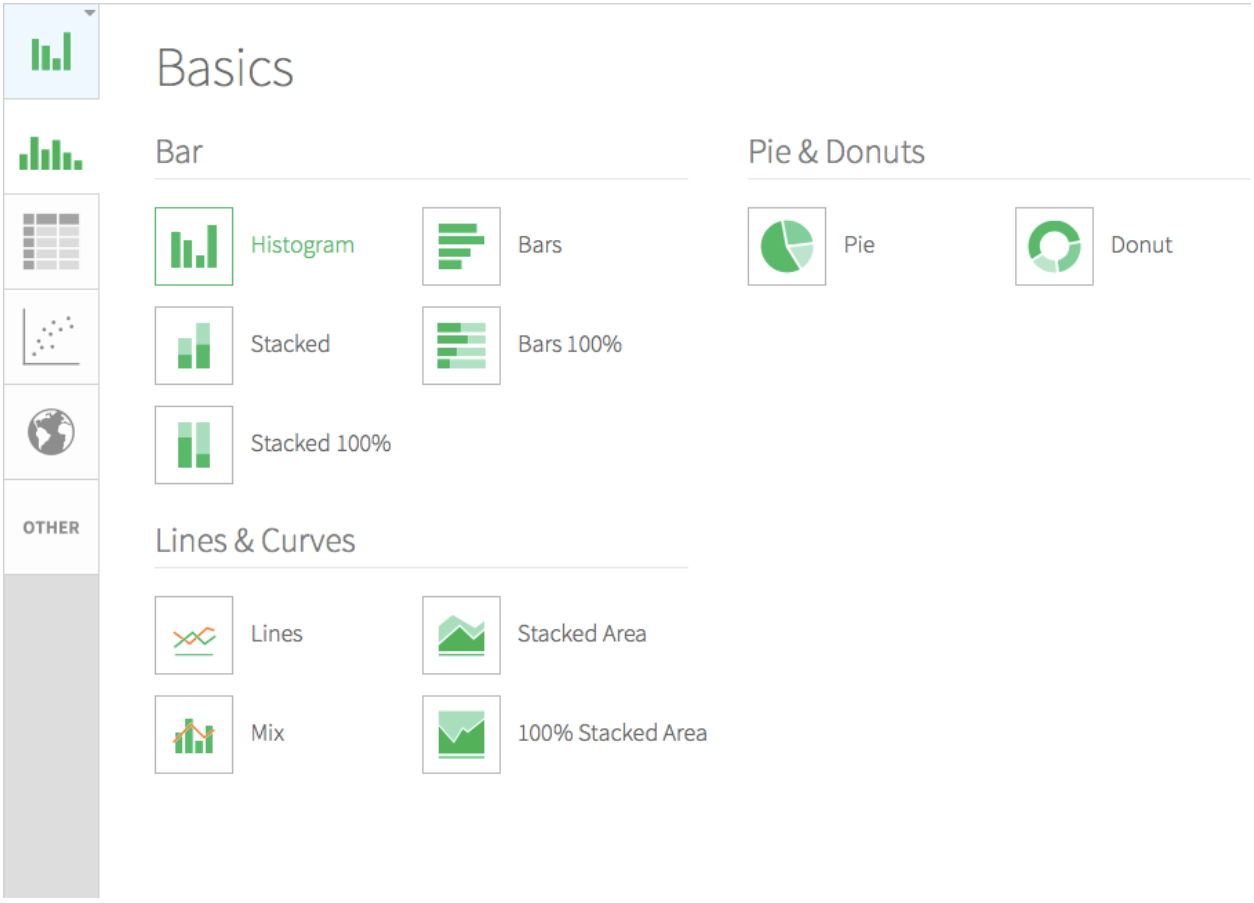

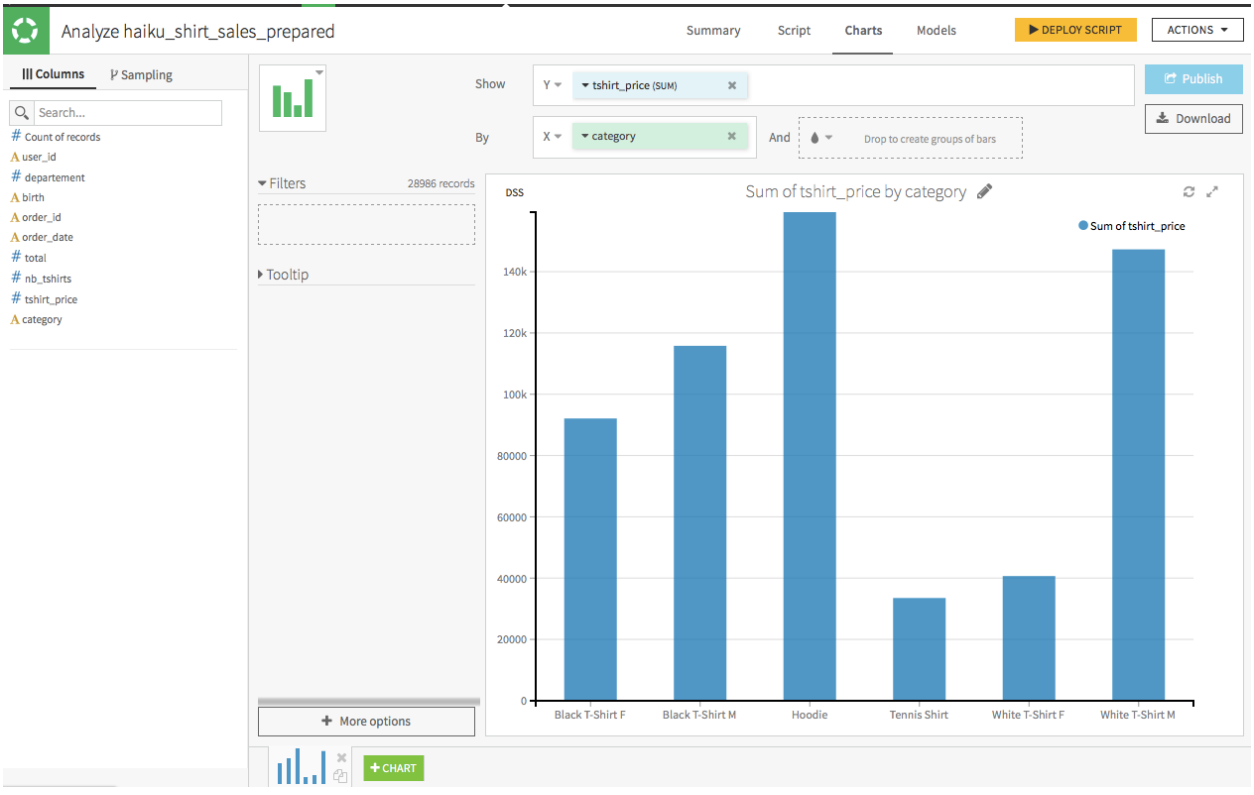

3.3 内容发布

我们可以根据已有的数据集，以及一些网页内容的代码编写，就能轻易发布一个Web应用。